BUNDESREPUBLIK DEUTSCHLAND



^{EPO}-Munich 83 28. Okt. 2004

REC'D 0 4 NOV 2004

Prioritätsbescheinigung über die Einrechung Pci einer Patentanmeldung

Aktenzeichen:

103 45 526.4

Anmeldetag:

30. September 2003

Anmelder/Inhaber:

Océ Document Technologies GmbH,

78467 Konstanz/DE

Bezeichnung:

Verfahren und System zum Erfassen von Daten aus maschinell lesbaren Dokumenten

IPC:

G 06 F 17/21

Die angehefteten Stücke sind eine richtige und genaue Wiedergabe der ursprünglichen Unterlagen dieser Patentanmeldung.

München, den 30. September 2004

Deutsches Patent- und Markenamt

Der Präsident

Im Auftrag

Ozierzon

PRIORITY DOCUMENT

SUBMITTED OR TRANSMITTED IN COMPLIANCE WITH RULE 17.1(a) OR (b)



.06/00 EDV-L

Océ Printing Systems GmbH Gewerblicher Rechtsschutz / EM

30.09.2003 2003ODT0902 DE

5

Verfahren und System zum Erfassen von Daten aus maschinell lesbaren Dokumenten

10

Die Erfindung betrifft ein Verfahren und ein System zum Erfassen von Daten aus maschinell lesbaren Dokumenten, wobei 15 die Daten einer Datenbank zugeordnet werden, in dem einzelne Daten möglichst automatisch dem Dokument extrahiert werden und in entsprechende Datenbankfelder eingetragen werden, wobei das erfindungsgemäße Verfahren und System das Erfassen von Daten betrifft, falls Daten für ein oder mehrere 20 bestimmte Datenbankfelder eines Dokumentes nicht mit der notwendigen Zuverlässigkeit extrahiert werden konnten.

Verfahren und Systeme zum Erfassen von Daten aus maschinell

30

35

lesbaren Dokumenten sind bekannt. Üblicherweise weisen die Systeme einen Scanner auf, mit welchem Vorlagen optisch abgetastet werden. Die hierbei erzeugten Dateien maschinell lesbare Dokumente und enthalten in der Regel Textelemente. Die Textelemente werden mit Hilfe einer OCR-Einrichtung in codierten Text umgesetzt. Den Dateien werden in der Regel vorbestimmte Formulare bzw. Templates zugeordnet, so dass anhand der Formulare gezielt bestimmte Informationen aus den Text enthaltenden Dateien ermittelt werden können. Diese Informationen werden zum Beispiel in einer Datenbank abgespeichert.

Derartige Verfahren und Systeme werden beispielsweise bei großen Firmen eingesetzt, um Rechnungen zu lesen. Die so extrahierten Daten können automatisch einer betriebswirtschaftlichen Software übermittelt werden.

5

10

15

20

35

Ein solches System ist in der US 4,933,979 beschrieben. Dieses System weist einen Scanner zum optischen Abtasten von Formularen auf. Bei diesem System können eine Vielzahl von Formulartypen definiert werden, wobei jeder Formulartyp bzw. Template durch mehrere Parameter, insbesondere geometrisch definierte Bereiche, in welchen Texte oder Bilder enthalten sein sollen, festgelegt ist. Die Formulartypen können auch durch weitere Eigenschaften, wie zum Beispiel der Schrift, die in den Texten enthalten ist (Alphabet, Zahlen, Symbole, Katakana, Kanji, Handschrift) definiert sein. Nach dem Scannen eines Formulars wird mittels Formulartypunterscheidungseinrichtung dem gescannten Formular ein Template zugeordnet. Dementsprechend werden die in dem Textfeld enthaltenen Daten mittels einer OCR-Einrichtung gelesen und extrahiert. Falls kein geeignetes Template vorhanden ist, muss eines erstellt werden.

MO. 98/47098 geht ein weiteres System automatischen Erfassen von Daten aus maschinell lesbaren Dokumenten hervor. Hierbei werden mittels eines Scanners Formulare optisch abgetastet. Danach wird automatisch eine Linien-Karte des Formulars erstellt. Hierbei werden zum einen alle Linien erfasst als auch grafische Elemente in eine Linienstruktur umgesetzt: Andere Elemente, wie zum Beispiel Textabschnitte, werden ausgefiltert. Alle vertikalen Linien bilden die Grundlage zur Erstellung eines vertikalen Schlüssels und alle horizontalen Linien bilden die Grundlage zur Erstellung eines horizontalen Schlüssels. Danach wird ermittelt, ob bereits ein Template mit korrespondierenden vertikalen und horizontalen Schlüssel vorhanden ist. Falls dies der Fall ist, werden die Daten mit einem entsprechenden Template ausgelesen. Ist dies nicht der Fall, so wird anhand des eingescannten Formulars mittels eines Selbstlern-Modus ein Template erstellt und abgespeichert.

In dem Buch Modern Information Retrieval von Baeza-Yates und Ribeiro-Neto, Eddison-Wessley Verlag, ISBN 0-201-39829-X sind Grundlagen von Datenbanken und zum schnellen in Datenbanken Wiederauffinden von gespeicherten Informationen erläutert. So ist im Kapitel 8.2 ein Verfahren mit invertierten Dateien, das auch als invertierter Index 10 bezeichnet wird, beschrieben. Bei diesem Verfahren wird aus einem zu untersuchenden Text zunächst ein Wörterbuch mit allen im Text enthaltenen Wörtern erstellt. Allen Wörtern des Wörterbuches werden eine oder mehrere Zahlen zugeordnet, die 15 angeben, an welcher Stelle das Wort im Text auftritt. Derartige invertierte Dateien erlauben eine schnellere automatische Analyse eines zu durchsuchenden Textes. Kapitel 8.6.1 ist ein String Matching-Verfahren beschrieben, mit welchem zwei Strings verglichen werden und ein zur Ähnlichkeit der Strings indirekt proportionales Kostenmaß 20 berechnet wird. Wenn die beiden Strings identisch sind, ist der Betrag des Kostenmaßes Null. Je stärker sich die Strings unterscheiden, desto größer ist der Betrag des Kostenmaßes. Das Kostenmaß ist somit ein Ausdruck für die Ähnlichkeit der beiden Strings. Dieses und ähnliche Verfahren sind auch unter den Bezeichnungen Approximate String Matching, Levenshtein-Verfahren, Elastic Matching und Viterbi-Algorythmus bekannt. gehören zu dem Gebiet Diese Verfahren der dynamischen Programmierung.

30

35

Aus der noch nicht veröffentlichten Patentanmeldung DE 103 42 594.2 geht ein Verfahren und ein System zum Erfassen von Daten aus mehreren maschinell lesbaren Dokumenten hervor, bei dem aus einem zu bearbeitenden Dokument, dem Lesedokument, Daten extrahiert werden, indem sie an Positionen aus dem Lesedokument ausgelesen werden, die durch in einem Vorlagedokument eingetragene Felder bestimmt sind.

Tritt ein Fehler beim Auslesen der Lesedokumente auf, wird Lesedokument an einem Bildschirm dargestellt und entsprechender Felder lediglich durch Markieren ·im Lesedokument können die Daten ausgelesen werden. Hierbei erforderlich ist, automatisch weitere falls es werden, Vorlagedokumente anhand der markierten Lesedokumente erstellt bzw. vorhandene Vorlagedokumente entsprechend korrigiert. Dieses System ist derart einfach bedienbar, so dass keine speziellen Computer- oder Softwarekenntnisse notwendig sind.

5

10

15

20

30

35

Der Erfindung liegt die Aufgabe zugrunde, ein Verfahren und ein System zum Erfassen von Daten aus maschinell lesbaren Dokumenten zu schaffen, bei dem die Eingabe der Daten gegenüber dem bekannten Verfahren erheblich vereinfacht wird, falls Daten nicht automatisch extrahiert werden konnten.

Die Aufgabe wird durch ein Verfahren mit den Merkmalen des Anspruchs 1 und durch ein System mit dem Merkmal des Anspruchs 16 gelöst. Vorteilhafte Ausgestaltungen der Erfindung sind in den jeweiligen Unteransprüchen angegeben.

Mit den oben erläuterten Verfahren können Daten aus mehreren maschinell lesbaren Dokumenten erfasst werden, wobei die Daten einer Datenbank zugeordnet werden, indem einzelne Daten möglichst automatisch dem Dokument extrahiert werden und in entsprechende Datenbankfelder eingetragen werden. Falls Daten für ein oder mehrere bestimmte Datenbankfelder einem Dokument nicht mit der notwendigen Zuverlässigkeit extrahiert werden konnten, zum Beispiel weil ein Fehler festgestellt worden ist, der beispielsweise dadurch verursacht sein kann, dass in dem Dokument an der Stelle, wo die Daten gelesen werden sollten, keine Daten oder falsche Daten vorhanden sind, oder dass beim Einlesen dieses Dokumentes mittels eines OCR-Verfahrens ein oder mehrere Zeichen falsch umgesetzt werden, so werden erfindungsgemäß folgende Schritte ausgeführt:

- Darstellen des Dokumentes an einem Bildschirm,
- Anzeigen des Datenbankfeldes, für das die Daten nicht mit der notwendigen Zuverlässigkeit extrahiert werden konnten, am Bildschirm
- 5 Ausführen einer Vorschlags-Routine, mit welcher Stringabschnitte in der Nähe eines von einem Benutzer auf dem Bildschirm bewegbaren Zeiger ausgewählt, markiert und zur Extraktion vorgeschlagen werden.
- 10 Das Dokument wird am Bildschirm dargestellt, damit der lesen kann. Zudem .wird das Datenbankfeld Benutzer es angezeigt, für das die Daten nicht mit der notwendigen Zuverlässigkeit extrahiert werden konnten. Hierdurch wird der in Kenntnis darüber gesetzt, für Datenbankfeld die Daten aus dem am Bildschirm dargestellten 15 Dokument noch zu extrahieren sind.

. 20

Durch das Ausführen bzw. Aktivieren der Vorschlags-Routine werden Stringabschnitte in der Nähe eines von dem Benutzer auf dem Bildschirm bewegbaren Zeiger ausgewählt, markiert und zur Extraktion vorgeschlagen. Hierdurch muss der Benutzer lediglich den Zeiger auf den am Bildschirm dargestellten Dokument in die Nähe eines Stringabschnittes bewegen, der die Daten für das angezeigte Datenbankfeld enthält. Die Daten werden dann automatisch ausgewählt, markiert und zur Extraktion vorgeschlagen. Der Benutzer kann dann lediglich durch Betätigen einer bestimmten Taste den vorgeschlagenen Stringabschnitt in das Datenbankfeld übernehmen.

- 30 Durch das automatische Auswählen und Markieren des Stringabschnittes wird der Vorgang der Übernahme der noch fehlenden Daten erheblich vereinfacht und beschleunigt.
- Nach einer bevorzugten Ausführungsform der Erfindung werden 35 beim Auswählen des Stringabschnittes Konzept-Informationen berücksichtigt, die dem jeweiligen Datenbankfeld zugeordnet sind.

Die Erfindung wird nachfolgend beispielhaft anhand der Zeichnung näher erläutert. In der Zeichnung zeigen:

- 5 Figur 1 ein Verfahren zum Erfassen von Daten aus einem Dokument, die nicht automatisch extrahiert werden konnten,
- Figur 2 6 jeweils Kopien von Bildschirmdarstellungen zu

 10 einzelnen Verfahrensschritten des in Figur 1
 gezeigten Verfahrens,
 - Figur 7 ein Verfahren zum Extrahieren von in Tabellen angeordneten Daten,
 - Figur 8, 9 jeweils eine Tabelle mit markierten Daten, und

15

20

30

35

Figur 10 ein System zum Ausführen des erfindungsgemäßen Verfahrens.

Das erfindungsgemäße Verfahren zum Erfassen von Daten aus maschinell lesbaren Dokumenten ist eine Weiterbildung der eingangs erläuterten Verfahren, mit welchen aus Dokumenten maschinell Daten extrahiert und in einer Datenbank gespeichert werden können.

diesen Verfahren können jedoch nicht immer alle Datenbankfelder der Datenbank zuverlässig mit aus Dokumenten extrahierten Daten gefüllt werden. Liegt zum Beispiel beim Extrahieren der Daten ein Fehler vor, so wird das automatische Verfahren unterbrochen und unter Mitwirkung eines Benutzers werden die Daten aus dem Dokument manuell in Datenbankfelder übertragen. Ein solcher Fehler kann dadurch verursacht sein, dass in dem zu bearbeitenden Dokument kein geeigneter Stringabschnitt gefunden wird, aus dem die Daten gelesen werden können oder der Stringabschnitt fehlerhafte Daten enthält, die beispielsweise beim Umsetzen in codierten

• • •

Text des Dokumentes mittels eines OCR-Verfahrens entstanden sind.

Das erfindungsgemäße Verfahren beginnt somit dann, Daten nicht zuverlässig extrahiert werden können. Der Ausdruck "nicht zuverlässig extrahierbar" umfasst sowohl grundsätzliche Fehler beim Lesen von Daten, die ein Lesen der Daten nicht möglich machen als auch gelesene Daten, die zum Beispiel unter Berücksichtigung von Kontext-Informationen auf das Datenbankfeld abgebildet werden, wobei die Güte der Abbildung ermittelt wird. Derartige Abbildungsverfahren sind zum Beispiel das eingangs erläuterte String Matching-Verfahren. Ist die hierbei erzielte Abbildungsgüte zu gering, so werden die automatisch eingelesenen Daten als nicht ausreichend zuverlässig bewertet und verworfen.

Nachfolgend wird das erfindungsgemäße Verfahren anhand des in Figur 1 dargestellten Flussdiagramms erläutert. In dem Flussdiagramm sind alle Schritte, die automatisch ausgeführt werden, mit einem "a" im Kreis und alle vom Benutzer manuell zu tätigenden Schritte mit einem "m" im Kreis gekennzeichnet.

Es beginnt mit dem Schritt S1.

5

10

15

20

Nachdem zumindest Daten für ein Datenbankfeld nicht mit der notwendigen Zuverlässigkeit extrahiert werden konnten, wird entsprechende Dokument 1 an Bildschirm einem dargestellt und das Datenbankfeld 3 angezeigt (Schritt S2). Figur 2 zeigt eine Bildschirmdarstellung unmittelbar nach dem 30 Feststellen, dass Daten nicht mit der notwendigen Zuverlässigkeit extrahiert werden konnten, wobei in einem Fenster 4/1 auf der rechten Seite der Bildschirmdarstellung das Dokument 1 dargestellt ist. Auf der linken Seite sind zwei Fenster 4/2 und 4/3 angeordnet. Das Fenster 4/2 enthält eine Übersicht der zu bearbeitenden Dokumente und im Fenster 35 4/3 sind die einzelnen Datenbankfelder angegeben, in welche

Daten gespeichert werden, die aus dem Dokument 1 zu lesen sind.

In dem dargestellten Beispiel konnte keines der Datenbankfelder mit Daten gefüllt werden, weshalb die einzelnen Datenbankfelder 3 mit dem Zusatz [empty] versehen ist jedoch auch möglich, dass nur in wenigen Datenbankfeldern oder lediglich in einem einzigen Datenbankfeld Daten fehlen.

10

15

5

- In Figur 2 ist das Datenbankfeld "InvoiceNumber" (= Rechnungsnummer) im Vergleich zu den anderen Datenbankfeldern 3 dunkler markiert, was dem Benutzer anzeigt, dass für dieses Datenbankfeld 3 Daten aus dem Dokument 1 zu extrahieren sind. Zusätzlich ist im oberen Bereich des Fensters 4/1 in großer Schrift der Begriff "InvoiceNumber" aufgeführt, das dem Benutzer zusätzlich anzeigt, für welches Datenbankfeld Daten zu extrahieren sind.
- 20 . Benutzer kann nun im Fenster 4/1 einen Zeiger 5 positionieren, den er vorzugsweise derart anordnet, dass er sich möglichst nahe an dem Stringabschnitt befindet, von dem Benutzer annimmt, dass dessen Inhalt in dem entsprechenden Datenbankfeld abzuspeichern ist. In dem in Figur 2 gezeigten Beispiel sind Daten für das Datenbankfeld "Rechnungsnummer" zu extrahieren, weshalb der Zeiger 5 in der Nähe der Rechnungsnummer "4361" positioniert wird (Schritt S3).
- 30 Der Zeiger 5 kann hierbei mittels einer Maus 6 oder durch Eingabe an einer Tastatur 7 im Fenster 4/1 bewegt werden.

Nach dem Positionieren des Zeigers 5 beginnt eine Vorschlags-Routine, die mehrere Verfahrensschritte umfasst.

Diese Vorschlags-Routine kann einerseits dadurch ausgelöst werden, dass der Zeiger 5 ein vorbestimmtes Zeitintervall nicht bewegt wird, wodurch dann die Vorschlags-Routine

automatisch ausgeführt wird, oder dadurch, dass eine bestimmte Taste einer Maus oder der Tastatur bestätigt wird.

5

10

15

20

30

Im Schritt S4 wird zunächst geprüft, ob in der näheren Umgebung des Zeigers ein Stringabschnitt mit einem für das Datenbankfeld 3 geeigneten Konzept vorhanden ist, sofern dem Datenbankfeldes des entsprechenden Typ wurden. Diese zugeordnet Konzeptinformationen Syntax und/oder die umfassen Konzeptinformationen die Semantik des Datenbankfeldes. Informationen zur Syntax sind zum Beispiel die Anzahl von Ziffern und/oder Buchstaben lesenden und/oder vorbestimmte Formate des zu Stringabschnittes. So weisen Datumsfelder, Betragsfelder und bestimmte Format'e Adressfelder in der Regel Informationen zur Semantik umfassen vorbestimmte Begriffe, entsprechende Datenbankfeld eingefügt werden. können. Dies ist zum Beispiel bei Währungsangaben zweckmäßig, oder wenn die Artikelbezeichnung eines bestimmten Lieferanten eingelesen werden sollen, der eine begrenzte Anzahl von kann. Die entsprechenden liefern Artikeln Artikelbezeichnungen sind dann in einem Lexikon abgelegt und können dann eindeutig erkannt werden.

dargestellten Ausführungsbeispiel Bei dem in Figur 2 Zeigers 5 die sich in der Nähe des befinden "4361° und "02.08.2002". Der letzte Stringabschnitte Stringabschnitt besitzt die Syntax eines Datums, weshalb er zum Extrahieren der Rechnungsnummer verworfen wird. Der "4361" entspricht der Syntax einer · Stringabschnitt Rechnungsnummer. Somit wird im Schritt S4 entschieden, dass ein Stringabschnitt mit einem geeigneten Konzept vorliegt, weshalb der Verfahrensablauf auf den Schritt S5 übergeht. Im Schritt S5 wird der Stringabschnitt "4361" markiert (Figur Markierung . erfolgt im 3). Die durch eine farbliche Unterlegung Ausführungsbeispiel Stringabschnittes und durch Zeichnen eines Rahmens 8. .

Sollte im Schritt S4 kein geeignetes Konzept ermittelt werden, so geht der Verfahrensablauf auf den Schritt S6 über. Im Schritt S6 wird das zum Zeiger 5 nächstliegend angeordnete Einzelzeichen ermittelt, das im vorliegenden Ausführungsbeispiel gemäß Fig. 2 - 4 die "1" ist. Danach Grenzen des dieses Zeichen enthaltenden Stringabschnittes nach allgemeinen Regeln ermittelt. Diese Grenzen können zum Beispiel durch Leerzeichen bzw. Leerräume im Dokument 1 oder durch bestimmte Satzzeichen oder sonstige Markierungen im Dokument 1 vorgegeben sein. entsprechende Begrenzungsmarkierungen erkannt, so wird der dazwischen liegende Stringabschnitt ausgewählt und markiert. Bei dem in Figur 2 und 3 gezeigten Ausführungsbeispiel befinden sich seitlich des Stringabschnittes "4361" jeweils Leerräume, durch die auch nach den allgemeinen Regeln eine eindeutige Auswahl der Markierung des Stringabschnittes möglich ist.

5

10

15

20

30

Unabhängig davon, ob der Stringabschnitt gemäß dem Schritt S5 oder gemäß dem Schritt S6 ausgewählt oder markiert worden ist, geht der Verfahrensablauf auf den Verfahrensschritt S7 über, mit der der Stringabschnitt in einem zusätzlichen Rahmen 9 als codierter Text und in einem weiteren Rahmen 10 vergrößert dargestellt wird (Fig. 3, 4). Bei dem vorliegenden Ausführungsbeispiel liegt das Dokument 1 als grafische Datei, zum Beispiel im pdf, tif, gif, jpg-Format vor. Üblicherweise wird in dem bereits vorausgegangenen Verfahrensabschnitt das Dokument einer OCR-Routine unterzogen und in codierten Text umgesetzt. Der codierte Text ist hierbei auch auf Konzepte untersucht worden und die entsprechenden Informationen sind abgespeichert worden. Diesem codierten Text wird der zu dem Stringabschnitt korrespondierende Abschnitt entnommen und in dem Rahmen 9 dargestellt. Hierdurch erkennt der Benutzer, ob Stringabschnitt korrekt in codierten Text umgesetzt worden ist.

Im Rahmen 10 wird der Stringabschnitt im Grafikformat in vergrößerter Darstellung dargestellt, wodurch der Benutzer auch Details im Stringabschnitt erkennen kann.

5 Mit dem Schritt S7 ist die Vorschlags-Routine abgeschlossen.

10

15

20

30

Im Schritt S8 beurteilt der Benutzer, ob der ausgewählte und markierte Stringabschnitt grundsätzlich zur Übernahme in das Datenbankfeld geeignet ist. Ist dies nicht der Fall, so wird der Zeiger 5 erneut positioniert (S3) und die Vorschlags-Routine (S4 - S7) wiederholt ausgeführt. Ist die Auswahl des Stringabschnitts hingegen grundsätzlich geeignet, beurteilt der Benutzer, ob auch der markierte Bereich korrekt ist (Schritt S9). Ist dies nicht der Fall, so kann der Benutzer die Markierung des Stringabschnittes manuel1 bearbeiten und/oder den codierten Text im Rahmen 9 editieren (Schritt S10). Mit dem Editieren des codierten Textes können Fehler, die durch eine nicht korrekte OCR-Umsetzung entstanden sind, behoben werden. Bei diesen Korrekturen (Bereich anpassen, Editieren) werden automatisch markierte Bereich und die Inhalte der Rahmen 9 und 10 angepasst.

Ist der markierte Bereich korrekt bzw. vom Benutzer entsprechend überarbeitet worden, so geht Verfahrensablauf auf den Schritt S11 über, mit dem die in dem ausgewählten Stringabschnitt enthaltenen Daten in korrespondierende Datenbankfeld übertragen werden (Figur 4). Diese Übertragung der Daten wird durch eine Betätigung einer vorbestimmten Taste an der Maus oder der Tastatur vom Benutzer ausgelöst. Danach ist das Verfahren zum Extrahieren von Daten für ein Datenbankfeld beendet (S12). Sind Daten für weitere Datenbankfelder zu lesen, so beginnt das Verfahren erneut mit dem Schritt S1. In Figur 5 ist das nächste zu lesende Datenbankfeld "Invoice Date" (= Rechnungsdatum) angezeigt.

Mit dem erfindungsgemäßen Verfahren wird die Tätigkeit eines Benutzers beim manuellen Übertragen von Daten aus einem Dokument in ein Datenbankfeld lediglich auf das Positionieren des Zeigers, der Kontrolle der automatisch vorgeschlagenen Auswahl und der eventuellen Korrektur des Bereiches und das Betätigen einer Taste zum Übertragen der Daten beschränkt. Die Auswahl und die Markierung des Bereichs des auszuwählenden Stringabschnittes wird vom erfindungsgemäßen Verfahren selbsttätig ausgeführt.

10

Die Figuren 2 bis 5 zeigen die Übernahme von Daten in ein einzelnes Datenbankfeld. Durch die Berücksichtigung von Konzept-Informationen ist es jedoch auch möglich, mit einem einzigen Stringabschnitt Daten für mehrere Datenbankfelder zu extrahieren. Figur 6 zeigt ein entsprechendes Ausführungsbeispiel, in dem die vollständige Adresse als ein Stringabschnitt markiert und gelesen wird, wobei die Adresse selbsttätig in die einzelnen Datenbankfelder, Name, Firma, Straße, Postleitzahl und Stadt segmentiert wird.

20

35

15

Nachfolgend wird eine weitere Ausgestaltung des oben beschriebenen Verfahrens anhand des Flussdiagrammes aus Figur 7 und der Bildschirmdarstellungen gemäß Figur 8 und 9 erläutert, mit dem Daten aus Tabellen extrahiert werden können.

Dieses Verfahren beginnt mit dem Schritt S15.

Im Schritt S16 werden die Werte der Tabelle in der ersten Tabellenzeile gemäß obigen Verfahren durch Positionieren des Zeigers, automatisches Auswählen und Markieren des Stringabschnittes und Übernehmen der Daten in korrespondierende Datenbankfelder extrahiert. Figur 8 zeigt Tabelle, in der die Stringabschnitte der Tabellenzeile markiert sind, die in die entsprechenden Datenbankfelder übernommen worden sind. Diese Datenbankfelder besitzen die Struktur einer Tabelle, zum Beispiel sind sie als zwei-dimensionales Datenfeld angelegt, so dass beim Extrahieren der Daten in diese Datenbankfelder das Verfahren anhand des Datenbankfeldes selbsttätig erkennt, dass Daten aus einer Tabelle ausgelesen werden.

5

Eine Tabellenzeile kann sich auch über mehrere erstrecken, wenn die Tabelle sich entsprechend über mehrere Seiten erstreckt. Sind die Daten der ersten Tabellenzeile vollständig extrahiert worden, kann der Benutzer durch eine 10 vorbestimmte Eingabe das automatische Extrahieren der weiteren Tabelleneinträge initiieren. Wird diese Eingabe vom Benutzer getätigt, so werden im Schritt S17 zunächst eine Liste mit allen Stringabschnitten erstellt, die unterhalb der ersten Tabellenzeile angeordnet sind.

15 ·

30

S18 wird mittels einer Kostenfunktion ein Schritt Kostenwert zwischen Sequenzen von Stringabschnitten der Liste und der Sequenz der Stringabschnitte der ersten Tabellenzeile, auf deren - Grundlage Daten in die 20 Datenbankfelder im Schritt S16 extrahiert worden ermittelt. Bei dieser Kostenfunktion werden den Sequenzen der Stringabschnitte der Liste geringe Kosten zugewiesen, deren Stringabschnitte bezüglich ihrer horizontalen Position und ihrer Breite mit den korrespondierenden Stringabschnitten der ersten Tabellenzeile übereinstimmen oder zumindest sehr ähnlich sind. Dieser Kostenwert ist somit indirekt proportional zur Ähnlichkeit zwischen den in der Liste aufgeführten Sequenzen von Stringabschnitten und den in der ersten Tabellenzeile enthaltenen Sequenz Stringabschnitten.

Die hierbei verwendete Kostenfunktion entspricht der aus dem Kapitel 8.6.1 String Matching Allowing Errors in Modern Information Retrieval (ISBN 0-201-39829-X) beschriebenen 35 Kostenfunktion, mit welcher jeweils ein Einzelkostenwert zwischen einem Stringabschnitt der ersten Tabellenzeile und

wird. Da jede Sequenz mehrere Stringabschnitte umfasst, wird mittels des Viterbi-Algorithmus für die einzelnen Sequenzen von Stringabschnitten jeweils ein Gesamtkostenwert bzw. Gesamtähnlichkeitswert durch Summieren der Einzelkostenwerte berechnet.

Anhand dieser Kostenwerte bzw. Ähnlichkeitswerte werden die Sequenzen von Stringabschnitten als Tabellenzeilen bestimmt, deren Ähnlichkeitswert unter einem vorbestimmten Schwellwert liegt (S19). Hierdurch sind alle Tabellenzeilen und damit Tabelleneinträge der Tabelle bestimmt. Sie werden im Schritt S20 markiert (Figur 9) und im Schritt S21 extrahiert, d.h., automatisch ausgelesen, gegebenenfalls in codierten Text umgesetzt, und in den entsprechenden Datenbankfeldern gespeichert.

Mit dem Schritt S22 ist dieses Verfahren beendet.

10

15

. 20

30

35

Zweckmäßigerweise ist es möglich, die Tabelleneinträge nachzubearbeiten, d.h., die markierten Bereiche zu verändern (verschieben, vergrößern, verkleinern) bzw. einzelne Zeilen zu entfernen bzw. hinzuzufügen. Bei einer Nachbearbeitung werden die Einträge in den Datenbankfeldern automatisch entsprechend angepasst.

Zusätzlich kann beim Auslesen der Daten und Eintragen in die Datenbankfelder eine zusätzliche Kontrolle durch eine Abbildung mittels dem String Matching-Verfahren erfolgen, mit welcher bestimmt wird, wie gut die Einträge mit dem durch die einzelnen Datenbankfelder vorgegebenen Konzept übereinstimmen.

Weiterhin kann das erfindungsgemäße Verfahren mit dem in der deutschen Patentanmeldung DE 103 42 594.2 beschriebenen Verfahren zum Erfassen von Daten aus mehreren maschinell lesbaren Dokumenten kombiniert werden, weshalb auf die Patentanmeldung vollinhaltlich Bezug genommen wird und sie

durch Bezugnahme in die vorliegende Patentanmeldung inkorporiert wird.

Bei diesem Verfahren zum automatischen Erfassen von Daten mehreren maschinell lesbaren Dokumenten werden Vorlagedokumente mit einem Lesedokument verglichen und deren Ähnlichkeit bewertet. Das hierbei angewandte Verfahren kann auch zum Auslesen einer Tabelle angewendet werden, wobei die ausgewählten Stringabschnitte Sequenz der Tabellenzeile Vorlagedokument dem entsprechen und Kombinationen von Stringabschnitten der weiteren Tabellenzeilen den Lesedokumenten entsprechen.

5

10

15

20

30

Bei dem oben beschriebenen erfindungsgemäßen Verfahren zum Extrahieren von Daten aus Tabellen muss ein Benutzer lediglich den Zeiger zu den Tabelleneinträgen in der ersten Tabellenzeile bewegen und die Übernahme der dann automatisch ausgewählten und markierten Stringabschnitte als Daten für das entsprechende Datenbankfeld bestätigen. Nachdem er dies für alle Tabelleneinträge der ersten Tabellenzeile ausgeführt hat, muss er lediglich durch eine Eingabe das vollständige der weiteren Tabelleneinträge Auslesen initiieren. Verfahren . ermittelt dann selbstständig die Tabelleneinträge, markiert sie und extrahiert die Daten in die Datenbank.

Dies beschleunigt erheblich das Auslesen von Daten aus der Tabelle in eine Datenbank. Der Verfahrensabschnitt S17 bis S21 stellt daher eine eigenständige Erfindung dar, die jedoch bevorzugt in Kombination mit dem in Figur 1 dargestellten Verfahren, auf der sich der Schritt S16 bezieht, verwendet wird.

Figur 10 zeigt schematisch ein System zum Ausführen des erfindungsgemäßen Verfahrens. Dieses System 11 weist einen Computer 12 mit einer Speichereinrichtung 13, mit einer zentralen Prozessoreinrichtung (CPU) 14 und eine Interface-

Einrichtung 15 auf. Am Computer 12 sind ein Scanner 16, ein Bildschirm 2 und eine Eingabeeinrichtung 17 angeschlossen. Die Eingabeeinrichtung 17 umfasst eine Tastatur 7 und/oder eine Maus 6.

5

10

15

In der Speichereinrichtung 13 ist ein Softwareprodukt zum Ausführen des erfindungsgemäßen Verfahrens gespeichert, das an der CPU 14 ausgeführt wird. Mit dem Scanner 16 werden Dokumente erfasst und in eine elektronische umgewandelt. Diese elektronischen Dateien werden vom Computer eingelesen und eventuell mittels einer OCR-Routine und/oder eines Verfahrens zum Erkennen spezieller Syntax oder Semantik in der Datei vorverarbeitet. Danach werden die in den Dateien enthaltenen Dokumente entsprechen dem oben beschriebenen Verfahren mit dem System 11 bearbeitet. An der Eingabeeinrichtung 17 können die entsprechenden Eingaben vorgenommen werden, wobei diese sich lediglich auf Bewegen des Zeigers 5 und ein paar wenige Tastatureingaben beschränken. Gegebenenfalls werden die markierten Felder mittels Tastatur oder Mauseingabe verschoben oder durch Vergrößerung bzw. Verkleinerung angepasst oder der codierte Text editiert.

Die Erfindung ist oben anhand eines Ausführungsbeispiels erläutert worden. Im Rahmen der Erfindung sind hiervon Abwandlungen möglich. So kann zum Beispiel anstelle des Rahmens 8 lediglich der Rahmen 10 vorgesehen werden, in dem der ausgewählte Stringabschnitt vergrößert dargestellt wird. Dieser Rahmen 10 stellt auch eine Markierung

30 Stringabschnittes dar.

Bei dem oben erläuterten Ausführungsbeispiel werden die Dokumente eingescannt und liegen dann in einem Graphikformat vor. Das erfindungsgemäße Verfahren kann jedoch auch zum Lesen von Informationen aus Dokumenten angewandt werden, die bereits in codiertem Text vorliegen, wie zum Bespiel e-mails. Bei einer solchen Anwendung ist es selbstverständlich nicht

notwendig, dass die Dokumente mittels einer OCR-Routine in codierten Text umgesetzt werden.

Die Erfindung kann folgendermaßen kurz zusammengefasst 5 werden:

Die Erfindung betrifft ein Verfahren zum Erfassen von Daten aus maschinell lesbaren Dokumenten, wobei die Daten einer Datenbank zugeordnet werden.

10

Mit der Erfindung werden Stringabschnitte, die sich in der Nähe eines vom Benutzer bewegbaren Zeigers befinden, automatisch ausgewählt, markiert und deren Inhalt zur Übernahme in eine Datenbank vorgeschlagen.

15

Nach einer Weiterbildung des erfindungsgemäßen Verfahrens kann der Inhalt einer Tabelle vollautomatisch ausgelesen werden, wenn die Tabelleneinträge in einer ersten Tabellenzeile einmal gemäß obigen Verfahren ausgelesen worden sind.

30

35

20

Es wurden Ausführungsbeispiele der Erfindung beschrieben. Dabei ist klar, dass der Fachmann jederzeit Abwandlungen und Weiterbildungen angeben kann, die das erfindungsgemäße. Konzept benutzten. Weiterhin kann die Erfindung mittels elektronischen Komponenten (Hardware) als auch durch Computerprogrammelemente (Software oder Softwaremodule) realisiert werden. Die Erfindung wird dabei insbesondere aus einer Kombination von elektronischen Hardware-Elementen und Softwareelementen realisiert. Dementsprechend erfaßt die Erfindung auch Computerprogrammprodukte wie z.B. elektronische Datenträger (CD, DVD, Diskette, Bandlaufwerke) Komponenten, die über Computernetzwerke verbreitet werden und/oder auf Computern und insbesondere im Zwischenspeichern geladen, bereit gehalten und/oder Ablauf gebracht werden.

Bezugszeichenliste

- 1 Dokument
- 2 Bildschirm
- 5 3 Datenbankfeld
 - 4 Fenster
 - 5 Zeiger
 - 6 Maus
 - 7 Tastatur
- 10 8 Rahmen
 - 9 Rahmen
 - 10 Rahmen
 - 11 System
 - 12 Computer
- 15 13 Speichereinrichtung
 - 14 CPU · ·
 - 15 Interface-Einrichtung
 - 16 Scanner
 - 17 Eingabeeinrichtung

Patentansprüche

- 1. Verfahren zum Erfassen von Daten aus maschinell lesbaren wobei die Daten einer Datenbank zugeordnet werden, indem einzelne Daten möglichst automatisch dem Dokument extrahiert werden und in entsprechende Datenbankfelder eingetragen werden, und falls Daten für ein oder mehrere bestimmte Datenbankfelder einem Dokument nicht 10 mit der notwendigen Zuverlässigkeit extrahiert werden konnten, werden folgende Schritte ausgeführt:
 - Darstellen des Dokumentes an einem Bildschirm,

15

20

- Anzeigen des Datenbankfeldes, für das die Daten nicht mit der notwendigen Zuverlässigkeit extrahiert werden konnten, am Bildschirm,
- Ausführen einer Vorschlags-Routine, mit welcher Stringabschnitte in der Nähe eines von einem Benutzer auf dem Bildschirm bewegbaren Zeiger ausgewählt, markiert und zur Extraktion vorgeschlagen werden.
- 2. Verfahren nach Anspruch 1,
 d a d u r c h g e k e n n z e i c h n e t,
 dass der Stringabschnitt nach Maßgabe von dem Datenbankfeld
 zugeordneten Konzept-Informationen ausgewählt, markiert und
 zur Extraktion vorgeschlagen wird.
- 3. Verfahren nach Anspruch 2,
 d a d u r c h g e k e n n z e i c h n e t,
 dass die Konzept-Informationen die Syntax und/oder die
 30 Semantik des Datenbankfeldes beschreiben, so dass von der
 Vorschlags-Routine ein zu markierender Stringabschnitt
 entsprechend der Syntax bzw. der Semantik des jeweiligen
 Datenbankfeldes ausgewählt und markiert wird.
- 35 4. Verfahren nach Anspruch 3, dadurch gekennzeichnet,

dass die Informationen zur Syntax die Anzahl von Ziffern und/oder Buchstaben und/oder vorbestimmte Formate des zu lesenden Stringabschnitts beschreiben.

- 5 5. Verfahren nach Anspruch 3 oder 4,
 d a d u r c h g e k e n n z e i c h n e t,
 dass die Informationen zur Semantik vorbestimmte Begriffe,
 bspw. mit einem Lexikon, beschreiben.
- 10 6. Verfahren nach einem der Ansprüche 1 bis 5,
 d a d u r c h g e k e n n z e i c h n e t,
 dass ein Stringabschnitt ausgewählt wird, der zwischen zwei
 Begrenzungszeichen angeordnet ist.
- 7. Verfahren nach Anspruch 6,,
 dadurch gekennzeichen et,
 dass Begrenzungszeichen Leerzeichen und/oder Satzzeichen
 umfassen.
- 8. Verfahren nach einem der Ansprüche 1 bis 7,
 d a d u r c h g e k e n n z e i c h n e t,
 dass der Text von Dokumenten in grafischer Darstellung
 zunächst mit einem OCR-Verfahren in codierten Text umgesetzt
 wird und die Vorschlags-Routine zusätzlich zum markierten
 Stringabschnitt in grafischer Darstellung den codierten Text
 dieses Stringabschnittes darstellt.
 - 9. Verfahren nach einem der Ansprüche 1 bis 7, dadurch gekennzeichnet,
- 30 dass zusätzlich zum markierten Stringabschnitt dieser Stringabschnitt nochmals in vergrößerter Darstellung am Bildschirm angezeigt wird.
 - 10. Verfahren nach einem der Ansprüche 1 bis 9,
- dass die Vorschlags-Routine nach dem Markieren eines Stringabschnittes eine Funktion aktiviert, mit welcher durch

Betätigen einer oder mehrerer vorbestimmter Tasten der Inhalt des markierten Stringabschnittes in die Datenbank übernommen wird.

- 5 11. Verfahren nach einem der Ansprüche 1 bis 10,
 d a d u r c h g e k e n n z e i c h n e t,
 dass beim Ausführen der Vorschlags-Routine nach dem Bewegen
 des Zeigers eine vorbestimmtes Zeitintervall abgewartet wird,
 innerhalb dessen der Zeiger nicht bewegt werden darf, bevor
 ein Stringabschnitt ausgewählt wird.
 - 12. Verfahren zum Erfassen von Daten aus maschinell lesbaren Dokumenten, wobei die Daten einer Datenbank zugeordnet werden, insbesondere nach einem der Ansprüche 1 11,
- 15 dadurch gekennzeichnet, dass nach dem Einlesen von Daten aus einer ersten Tabellenzeile in korrespondierende Datenbankfelder automatisch die weiteren Tabelleneinträge durch letzten unterhalb Tabellenzeile Vergleich von der 20 angeordneten Stringabschnitten mit den Stringabschnitten der ersten Tabellenzeile, die den eingelesenen Daten entsprechen, ermittelt werden und diese weiteren Tabelleneinträge automatisch extrahiert werden.
 - 13. Verfahren nach Anspruch 12, dadurch gekennzeichnet, dass der Vergleich zwischen den Stringabschnitten mittels eines String Matching-Verfahrens erfolgt.
- 30 14. Verfahren nach Anspruch 12 oder 13, dadurch gekennzeichnet, dass die ermittelten Tabelleneinträge markiert werden.
 - 15. Verfahren nach Anspruch 14,
- 35 dadurch gekennzeichnet, dass Funktionen zum Editieren der markierten Tabelleneinträge bereitgestellt werden.

- 16. System zum Erfassen von Daten aus maschinell lesbaren Dokumenten umfassend einen Computer (12) mit einer Speichereinrichtung (13) und eine CPU (14), wobei in der Speichereinrichtung (13) ein Softwareprodukt zum Ausführen des Verfahrens nach einem der Ansprüche 1 15 gespeichert ist.
- 17. System nach Anspruch 16,
- 10 dadurch gekennzeichnet, dass das System eine Eingabeeinrichtung (17) in Form einer Maus (6) und/oder Tastatur (7) aufweist.
 - 18. System nach Anspruch 16 oder 17,
- 15 dadurch gekennzeichnet,
 dass das System einen Scanner (16) zum optischen Abtasten von
 Dokumenten aufweist.
- 19. Computerprogrammprodukt, das bei seinem Laden und 20 Ausführen auf einem Computer (12) ein Verfahren nach einem der Ansprüche 1 bis 15 bewirkt.

Zusammenfassung

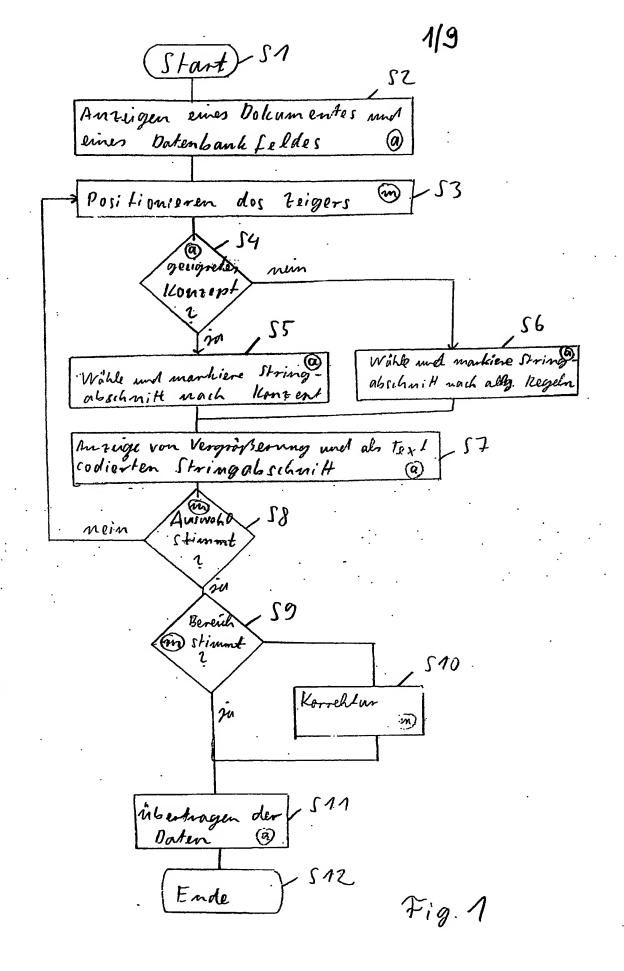
Die Erfindung betrifft ein Verfahren zum Erfassen von Daten 5 aus maschinell lesbaren Dokumenten, wobei die Daten einer Datenbank zugeordnet werden.

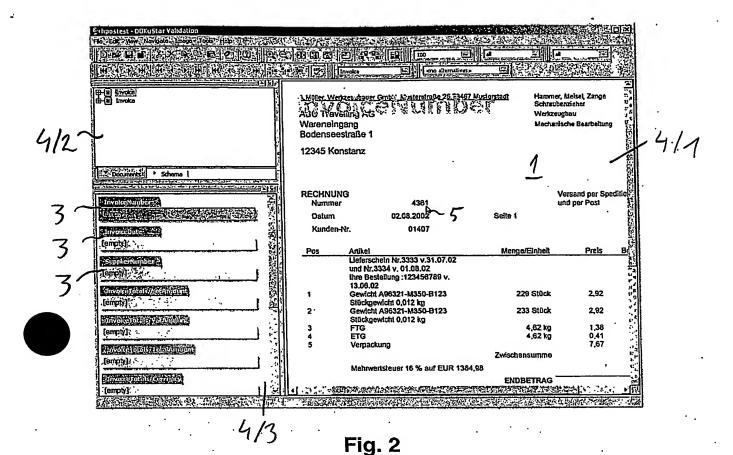
Mit der Erfindung werden Stringabschnitte, die sich in der Nähe eines vom Benutzer bewegbaren Zeigers befinden, 10 automatisch ausgewählt, markiert und deren Inhalt zur Übernahme in eine Datenbank vorgeschlagen.

Nach einer Weiterbildung des erfindungsgemäßen Verfahrens kann der Inhalt einer Tabelle vollautomatisch ausgelesen werden, wenn die Tabelleneinträge in einer ersten Tabellenzeile einmal gemäß obigen Verfahren ausgelesen worden sind.

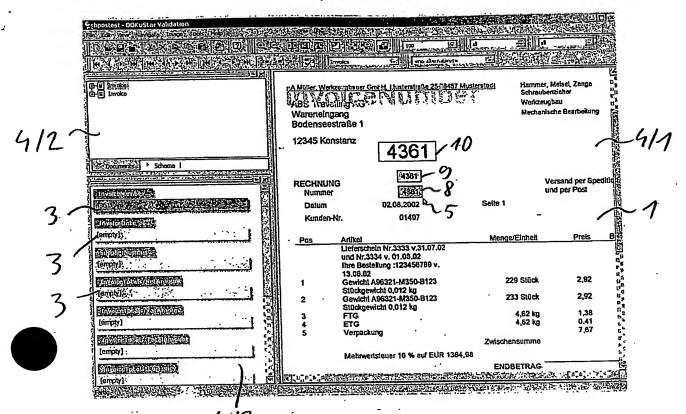
20 (Figur 3)

15





Maria A Mollier, Werkzer abouer Gmt 1 | fursterstraße 25-78467 Musterstedf Hammer, Meisel, Zange Schraubenzreher 412 . . ABC Traveling AG Werkzeugbau Wareneingang Bodenseestraße 1 12345 Konstanz 436 Documents Scheme | 4361 RECHNUNG Versand per Speditlo 4381 und per Post Nummer 02.08,2002 Datum Seite 1 Kunden-Nr. 01407 (empty) Menge/Einheil Pos Preis Bi Lieferschein Nr.3333 v.31.07.02 und Nr.3334 v. 01.08.02 thre Bestellung :123456789 v. [empty] 13 08 02 13.08.02 Gewicht A96321-M350-B123 Stückgewicht 0,012 kg Gewicht A96321-M350-B123 Stückgewicht 0,012 kg 229 Stück 2,92 (empty) 233 Stück 2,92 FTG ETG 4,62 kg 4,62 kg 1,38 0,41 7,67 (empty) Verpackung AND THE POST OF Zwischensumme (empty) Mehrwertsteuer 16 % auf EUR 1364,98 ENDBETRAG (empty) Fig. 3



TO AND THE PROPERTY OF THE PRO Date Plane A Moller, Werkzeughnuer GmbH, Mustersingte 25,78467 Musterstoot Hammer, Melsel, Zange Schraubenzieher Werkzeugbau Mechanische Be Wareneingang 4/2 Bodenseestraße 1 12345 Konstanz Documents Schema I Versand per Spedition RECHNUNG und per Post 4361 4361 Nummer 02.08,2002 Seite 1 Datum Kunden-Nr. B Preis Menge/Einheit Lieferschein Nr.3333 v.31.07.02 Lind Nr.3334 v. 01.08.02 Ihre Bestellung :123456789 v. 13.08.02 STATE OF THE STATE OF [vions] TOTAL CONTROL OF THE PARTY OF T Gewicht A98321-M350-B123 229 Silick 2,92 Stückgewicht 0,012 kg Gewicht A96321-M350-B123 [empty] 233 Stück 2,92 2 Stückgewicht 0,012 kg 4,62 kg 4,62 kg 1.38 0,41 FTG (empty) ETG 7.67 Verpackung involved a strata point Zwischensumme [empty] Mehrwertsteuer 16 % auf EUR 1364.98 ENDBETRAG enifer nemarks (empty) COLLEGE STATE Fig. 5

Fig. 4

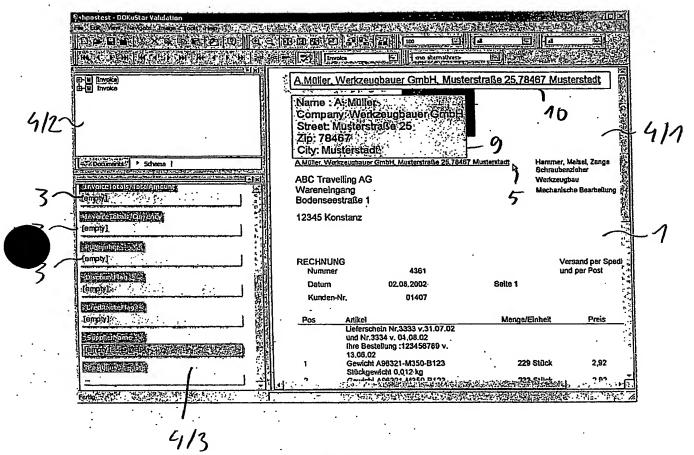


Fig. 6

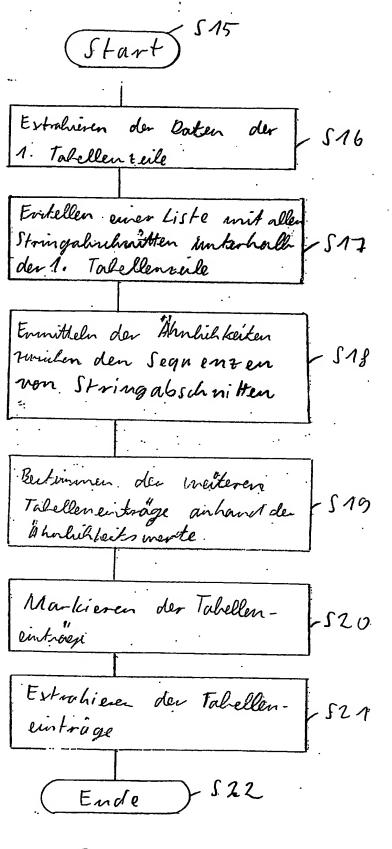
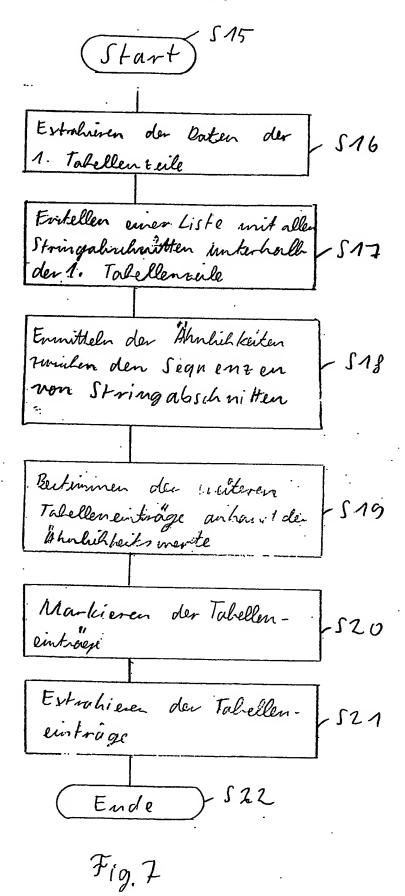


Fig. 7



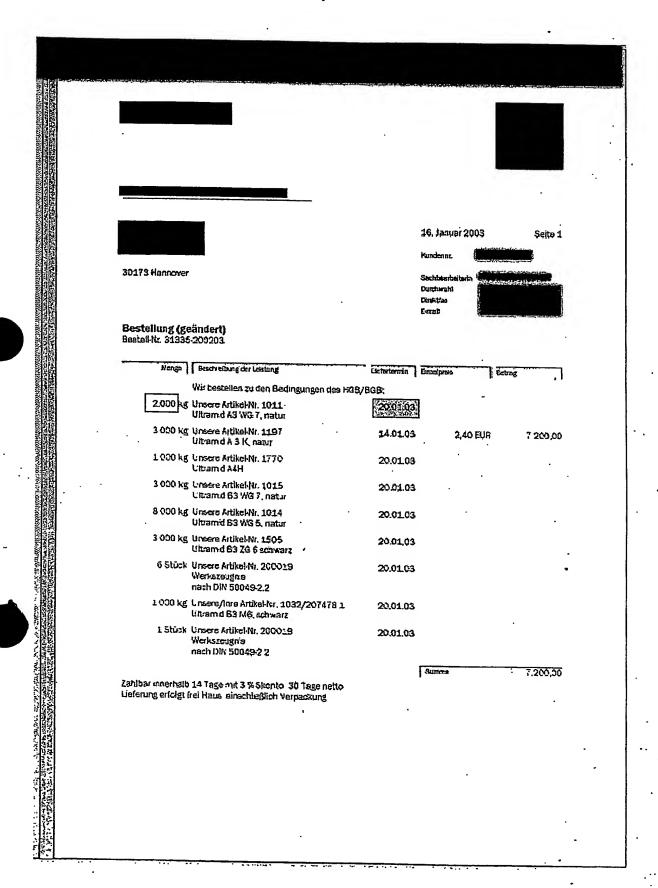


Fig. 8

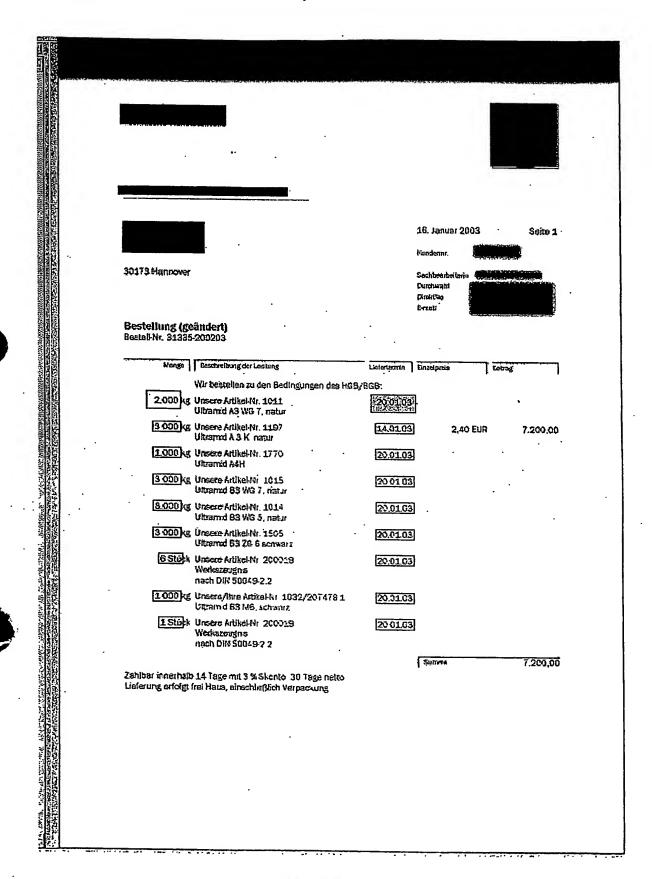
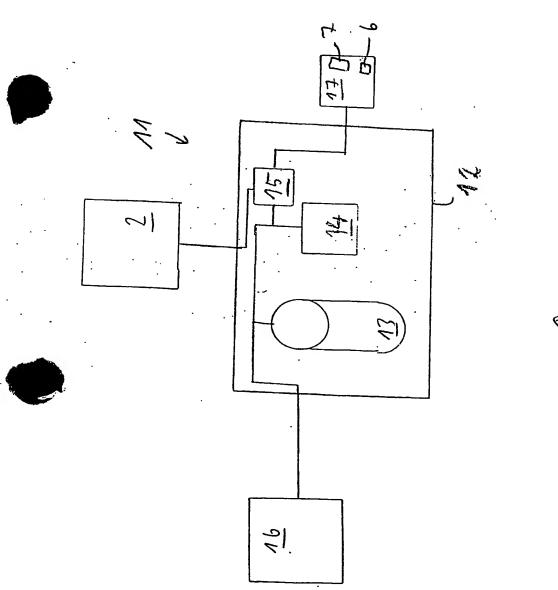


Fig. 9



F.19. 10.